

М.Н. ФАВОРСКАЯ, Н. НИШЧХАЛ
**ВЕРИФИКАЦИЯ РАЗЛИВОВ НЕФТИ НА ВОДНЫХ
ПОВЕРХНОСТЯХ ПО АЭРОФОТОСНИМКАМ НА ОСНОВЕ
МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ**

Фаворская М.Н., Нишчхал Н. Верификация разливов нефти на водных поверхностях по аэрофотоснимкам на основе методов глубокого обучения.

Аннотация. В статье решается задача верификации разливов нефти на водных поверхностях рек, морей и океанов по оптическим аэрофотоснимкам с использованием методов глубокого обучения. Особенностью данной задачи является наличие визуально похожих на разливы нефти областей на водных поверхностях, вызванных цветением водорослей, веществ, не приносящих экологический ущерб (например, пальмовое масло), бликов при съемке или природных явлений (так называемые «двойники»). Многие исследования в данной области основаны на анализе изображений, полученных от радаров с синтезированной апертурой (Synthetic Aperture Radar (SAR) images), которые не обеспечивают точной классификации и сегментации. Последующая верификация способствует сокращению экологического и материального ущерба, а мониторинг размеров площади нефтяного пятна используется для принятия дальнейших решений по устранению последствий. Предлагается новый подход к верификации оптических снимков как задачи бинарной классификации на основе сиамской сети, когда фрагмент исходного изображения многократно сравнивается с репрезентативными примерами из класса нефтяных пятен на водных поверхностях. Основой сиамской сети служит облегченная сеть VGG16. При превышении порогового значения выходной функции принимается решение о наличии разлива нефти. Для обучения сети был собран и размечен собственный набор данных из открытых интернет-ресурсов. Существенной проблемой является несбалансированность выборки данных по классам, что потребовало применения методов аугментации, основанных не только на геометрических и цветовых манипуляциях, но и на основе генеративной состязательной сети (Generative Adversarial Network, GAN). Эксперименты показали, что точность классификации разливов нефти и «двойников» на тестовой выборке достигает значений 0,91 и 0,834 соответственно. Далее решается дополнительная задача семантической сегментации нефтяного пятна с применением сверточных нейронных сетей (СНС) типа кодировщик-декодировщик. Для сегментации исследовались три архитектуры глубоких сетей, а именно U-Net, SegNet и Poly-YOLOv3. Лучшие результаты показала сеть Poly-YOLOv3, достигнув точности 0,97 при среднем времени обработки снимка 385 с веб-сервисом Google Colab. Также была спроектирована база данных для хранения исходных и верифицированных изображений с проблемными областями.

Ключевые слова: обнаружение разливов нефти, верификация, сегментация, глубокое обучение, аэрофотоснимки, дистанционное зондирование Земли.

1. Введение. Сырая нефть и нефтепродукты являются широко распространенными загрязнителями воды и почвы в результате разливов на водных поверхностях и на суше, динамика которых различна. Разливы нефти на водных поверхностях являются последствиями аварий на танкерах, судах, трубопроводах и нефтяных платформах, когда сырая нефть, бензин, топливо или побочные

продукты нефтепереработки сбрасываются в воду. Международная статистика по объемам разливов нефти свидетельствует о том, что большинство разливов нефти небольшие (менее 7 тонн), а крупные аварии составляют малую долю от общего количества нефти, попадающей в окружающую среду [1]. Однако даже небольшие аварийные выбросы сильно загрязняют локальные территории и не исключены пути, по которым нефть может попасть обратно к людям через накопления в рыбе или потребление загрязненных подземных вод.

Поскольку в настоящее время разведка нефти ведется в более глубоких водах и на более удаленных территориях, куда сложно попасть для своевременной очистки водных поверхностей, риск будущих аварий становится намного выше. Следует отметить, что из-за случайного характера разливов нефти их полное предотвращение невозможно. Атмосферные и водные условия (температура, ветер, течение, соленость) могут значительно увеличить перенос нефти и скорость выветривания. Следовательно, поведение и экологические последствия разливов в море или океане непредсказуемы и неопределенны [2], что приводит к необходимости построения модели предсказания поведения нефтяного пятна [3]. Воздушные, поверхностные и подповерхностные химические измерения показали, что около 5% массы выбрасываемых углеводородов испаряется в атмосферу, 10% составляет поверхностное пятно, а остаток растворяется или рассеивается в толще воды. Причем около одной трети углеводородов непосредственно находится в глубоких подводных течениях или накапливается в отложениях [4].

Процесс устранения последствий аварии может длиться долго, поэтому необходим мониторинг распространения разливов нефти для оценки влияния на экологическую безопасность окружающей среды. Общепринятым подходом является использование космических снимков или снимков, полученных от камер беспилотных летательных аппаратов или средств малой авиации, для обнаружения и мониторинга аварийной ситуации.

В данном исследовании решаются две связанные задачи – верификация разливов нефти на водных поверхностях и их сегментация с целью мониторинга последствий аварии. Результаты записываются в базу данных, что позволяет получать статистические данные, строить графики в указанный пользователем временной интервал.

2. Обзор существующих методов. Основными исходными данными для обнаружения и мониторинга разливов нефти

на водных поверхностях являются радарные и гиперспектральные / мультиспектральные космические снимки. При этом анализу радарных снимков посвящено большинство работ из-за основного преимущества – получение SAR снимков не подвержено метеорологическим факторам. Однако радарные снимки имеют существенные недостатки в виде спекл-шумов и ограничений в обнаружении относительно тонких нефтяных пленок. Также по радарным снимкам невозможно отличить биогенные пятна (например, цветение водорослей или другой растительности) и природные явления, вызванные ветром, течениями, вихоротоками, дождями и кильватерными следами кораблей (называемых в литературе «двойниками»), от разливов нефти [5, 6]. Улучшенные оценки распознавания показывают методы, обрабатывающие поляризованные SAR изображения [7, 8]. Отметим, что объективно как традиционные методы машинного обучения, так и методы глубокого обучения, применяемые для обработки радарных снимков, характеризуются худшими показателями относительно других видов снимков.

Если гиперспектральная визуализация аккумулирует излучение всей спектральной полосы для каждого пикселя изображения, то мультиспектральная визуализация характеризуется коэффициентами отражения ограниченного числа длин волн, связанных с видимой, инфракрасной и ультрафиолетовой частями гиперспектральных изображений. Их характеристики можно использовать как для обнаружения разливов нефти и для выявления «двойников» (эффекты флуоресценции, растительность и пр.). Перспективным подходом является совместное использование в алгоритмах как гиперспектральных, так и радарных космических снимков [9]. Оптические снимки предоставляют лучшие возможности для классификации и сегментации, однако существуют типичные ограничения в их получении средствами дистанционного зондирования Земли (ДЗЗ) (отсутствие облачности, дневное время суток). Поэтому оптические снимки, в основном, получают с использованием средств малой авиации, обеспечивая устойчивый мониторинг и относительно низкую стоимость их получения [10].

Эволюцию методов оценки разливов нефти можно сформулировать следующим образом. Классические методы машинного обучения, такие как линейный дискриминантный анализ, множественная линейная регрессия, кластеризация k -средних, методы логистической регрессии, деревья решений и т.д., применялись в 2000–2005 гг. В последующие годы стали использоваться усовершенствованные модели классификации (нечеткая

кластеризация, метаэвристическая оптимизация и модели на основе искусственные нейронных сетей). Быстрое распространение глубоких нейронных сетей, начиная с 2012 г., позволило объединить методы семантической и объектной сегментации SAR изображений с целью более точной классификации разливов нефти. В работе [7] многоуровневый автокодировщик и сеть глубокого доверия оптимизировали наборы признаков поляризованных SAR изображений за счет послыоного неконтролируемого предварительного обучения. Глубокая сверточная нейронная сеть с архитектурой, подобной семейству VGG-сетей, предложена в работе [6]. При этом значения верности (accuracy), полноты (recall) и точности (precision) составили 94,01%, 83,51%, и 85,7% для сегментации разливов нефти на SAR изображениях. Сеть глубокого обучения для обнаружения и категоризации разливов нефти на SAR изображениях в крупном масштабе на основе архитектуры U-Net предложена в работе [8]. Недавно предложенная модель BO-DRNet [11] основана на байесовской оптимизации гиперпараметров и архитектурах ResNet-18 и DeepLabv3+. Тем не менее, исследователи не ограничиваются применением методов глубокого обучения. Так, в работе [12] использована комбинация многоцелевой оптимизации алгоритма серых волков и k -средних для поиска наилучшего порогового уровня для сегментации SAR изображений.

Методов, относящихся к обработке оптических снимков для решения данной задачи, намного меньше. В работе [13] разработан интеллектуальный алгоритм обнаружения признаков разлива нефти на поверхности моря в виде двунаправленной семантической сети Ghost-DABiSeNetV2 со слоями «призрачной» свертки [14], на вход которой подаются дневные снимки видимого диапазона и ночные снимки инфракрасного диапазона. Спектральные свойства разливов нефти при наличии солнечных бликов изучались в работе [15]. Результаты исследований оптических свойств (отражательной способности и поглощения) эмульсий нефти в воде и воды в нефти с различными концентрациями под воздействием выветривания с целью интерпретации аэрофотоснимков представлены в работах [16, 17].

Отметим, что в последние годы обнаружение и мониторинг разливов нефти в арктических и около арктических широтах привлекает пристальное внимание исследователей [18, 19].

3. Постановка задачи. Из обзора существующих методов следует, что для достоверного распознавания разливов нефти SAR-снимков не достаточно. Обработку таких снимков можно рассматривать как первый этап решения задачи распознавания, во

время которого локализируются все регионы, похожие на разлив нефти и нефтепродуктов. Тем самым минимизируется ошибка «пропуска цели». На втором этапе распознавания требуется подтвердить, что регионы, похожие на разлив нефти и нефтепродуктов, действительно являются таковыми, иными словами, минимизируется ошибка «ложной тревоги». Дополнительно для уточнения геометрических характеристик регионов интереса выполняется семантическая сегментация, во время которой вычисляются глобальные признаки и все полученные данные записываются в базу данных мониторинга проблемной территории. Таким образом, верификация регионов изображения, похожих на разлив нефти (второй этап), является важной задачей, решение которой необходимо для принятия правильного решения экологического характера.

Сформулируем проблему распознавания как задачу бинарной классификации, которая подразумевает, что имеется класс нефтяных пятен и класс «двойников», куда попадают как органические субстанции, так и артефакты съемки. Бинарная классификация является простейшим случаем классификации. Пусть \mathbf{X} – множество всех возможных объектов в пространстве объектов, в данном случае нефтяных пятен и «двойников» различного происхождения. Пусть \mathbf{L} – пространство меток, а \mathbf{Y} – пространство выходов. Для решения задачи требуется построить модель, которая отображает пространство объектов в пространство выходов. При классификации пространством выходов является множество классов, в данном случае состоящее из двух элементов. Для обучения модели необходим обучающий набор помеченных объектов $(x, l(x))$, называемых примерами, где $l: \mathbf{X} \rightarrow \mathbf{L}$ – помечающая функция. При этом пространство меток совпадает с пространством выходов $\mathbf{L} = \mathbf{Y}$. Модель подвержена шуму, который может быть меточным (наблюдение искаженной метки l') или объектным (наблюдение искаженного объекта x'). Для предотвращения переобучения на шуме создается тестовый набор из помеченных данных. Отображение $\hat{c}(x): \mathbf{X} \rightarrow [0,1]$ называется бинарным классификатором, где $\hat{c}(x)$ – оценка истиной, но неизвестной функции $c(x)$. Обучающие примеры имеют вид $(x, c(x))$, где $x \in \mathbf{X}$ – объект, а $c(x)$ – истинный класс этого объекта. Под обучением классификатора понимается построение функции $\hat{c}(x)$, которая как можно лучше аппроксимирует истинную функцию $c(x)$ не только на обучающем наборе данных, но и на всем пространстве объектов \mathbf{X} .

Семантическая сегментация верифицированных объектов позволяет получить точный вывод на основе плотных прогнозов, иными словами, для каждого пиксела определяется метка класса. Поскольку в данном случае имеются только два класса, то на выходе сети типа кодировщик-декодировщик будет построена бинарная маска, по которой легко вычислить геометрические признаки объекта интереса.

4. Верификация фрагментов изображений разливов нефти оптическим снимкам. В условиях быстрого развития моделей и методов глубокого обучения технологии анализа оптических снимков, включая снимки ДЗЗ, позволяют получать результаты, иногда лучшие, чем экспертные оценки. Можно определить четыре категории признаков разливов нефти на водных поверхностях:

- геометрические признаки, характеризующие форму нефтяных пятен (площадь и периметр пятен);
- физические признаки, определяющие обратное рассеяние волн в физическом пространстве (среднее значение и стандартное отклонение коэффициента контрастности пятен);
- топологические признаки в ближайшем окружении (количество темных пятен вблизи основного нефтяного пятна);
- текстурные признаки, характеризующие поверхность нефтяного пятна (на основе текстурных признаков оценивается непрерывность пятна).

Считается, что геометрические признаки используются наиболее часто из-за относительной простоты их извлечения на SAR снимках. Так, в работе [20] вычислялись 9 видов геометрических признаков, включая собственные значения моментов X_u и эллиптических дескрипторов Фурье, для классификации разлива нефти многослойной сетью прямого распространения.

В данном исследовании использовались, в основном, текстурные и цветовые признаки для верификации разливов нефти. Задачу можно свести к задаче бинарной классификации, когда к одному классу относятся изображения нефтяных пятен, а к другому классу – визуальные артефакты «двойников» биогенного и природного происхождения. Оригинальным подходом является использование особой модели СНС – сиамской сети. Изначально сиамская сеть была предложена в работе [21] в 1993 г. для верификации подписи. Позднее принцип сиамской сети применялся для решения различных задач, включая классификацию изображений, повторную идентификацию человека, отслеживание объектов и др. Сиамская состязательная сеть

(Siamese Adversarial Network) является одной из последних модификаций данного семейства глубоких сетей.

Сиамская сеть состоит из двух идентичных подсетей с одинаковыми наборами весов. Она позволяет сравнивать векторы признаков двух объектов, чтобы выделить в них сходство или различие. Сиамская сеть может определить, принадлежат ли два сравниваемых изображения одному и тому же классу, даже если эти изображения ни разу не использовались во время обучения. Для классификации текстур рекомендуется выбирать такие модели, как AlexNet, VGG19, ResNet50, ResNet101, InceptionResnetV2, DenseNet201, InceptionV3 [22] или семантическую сеть семейства DeepLab [23]. Каждое семейство глубоких моделей имеют свои преимущества и недостатки. Проведенные эксперименты показали, что для данной задачи достаточно использовать относительно простые модели AlexNet или VGGNet. Таким образом, для реализации сиамской сети была выбрана облегченная сеть VGG16 [24].

Обучение сиамской сети осуществлялось методом самообучения, в частности, с использованием функции контрастной потери (contrastive loss function), которая оценивает, насколько хорошо сиамская сеть различает пары изображений. Следует отметить, что недавно разработанные методы самообучения основаны на сочетании двух понятий: контрастные потери и множество преобразований изображений. Контрастные потери не используют понятие экземпляров классов, а сравнивают признаки изображений непосредственно. В то же время преобразования изображений предполагают поиск инвариантных признаков [25].

Идеальная разделимость достигается, когда расстояние между классами в пространстве признаков становится большим, однако хорошей сходимости сети достичь трудно. Обычно стараются увеличить зазор между классами таким образом, чтобы расстояние положительных примеров было больше некоторого значения m , а расстояние отрицательных примеров – меньше некоторого значения n . После обучения примеры разделены зазором $m-n$. Иными словами, векторы признаков вносят вклад в функцию потерь только в том случае, если их параметризованное расстояние находится в пределах этого зазора. Тогда для положительных Pos и отрицательных Neg примеров можно записать следующие выражения:

$$Pos = \max\left(m - D_{s_1, s_2}, 0\right), \quad (1)$$

$$Neg = \max(D_{s_1, s_2} - n, 0), \quad (2)$$

где D_{s_1, s_2} – метрика расстояния между классами s_1 и s_2 . Для данной задачи выбрана Евклидова метрика:

$$D_{s_1, s_2}(\mathbf{y}_1, \mathbf{y}_2) = \|\mathbf{y}_1 - \mathbf{y}_2\|_2, \quad (3)$$

где \mathbf{y}_1 и \mathbf{y}_2 – выходные векторы признаков двух подсетей.

Из-за несбалансированности классов в обобщенной функции контрастной потери вводятся коэффициенты α и β , подбираемые эмпирически. Примем, что l – значение метки выходного класса, $l = [0, 1]$. Тогда функция контрастной потери $Loss_{CL}$ примет вид выражения (4):

$$Loss_{CL}(\mathbf{y}_1, \mathbf{y}_2, l) = \alpha(1-l) \max(m - D_{s_1, s_2}(\mathbf{y}_1, \mathbf{y}_2), 0) + \beta l \max(D_{s_1, s_2}(\mathbf{y}_1, \mathbf{y}_2) - n, 0). \quad (4)$$

На вход одной подсети поступает фрагмент изображения для классификации (патч, patch), в то время как на вход другой подсети подаются типовые фрагменты изображений нефтяных пятен. Обе подсети имеют одинаковую топологию СНС, включающую слои свертки, подвыборки (max-pooling) и полносвязные слои, формирующие векторы признаков. Значение контрастной потери рассчитывается как Евклидово расстояние между векторами признаков. Затем цикл повторяется, во время которого входной классифицируемый фрагмент сравнивается с другим типовым фрагментом. Иными словами, реализуется простейший ансамблевый метод бинарной классификации. Значения контрастных потерь суммируются, в результате чего выдается решение о принадлежности входного фрагмента классу нефтяных пятен. В ходе экспериментов было выявлено около 20 типовых фрагментов изображений нефтяных пятен, примеры которых представлены на рисунке 1. Количество типовых фрагментов, используемых для верификации входного фрагмента сиамской сети, выбирается исходя из обучающего набора данных. Если классификационный порог (50%) превышен, то считается, что входное изображение верифицировано как принадлежащее классу нефтяных пятен или не принадлежащее

данному классу. Процесс верификации фрагментов исходного изображения с помощью сиамской сети изображен на рисунке 2.



Рис. 1. Примеры фрагментов изображений нефтяных пятен

Вторая ветвь является обученной на нескольких десятках тысяч фрагментов (патчей) с разрешением 128×128 пикселей, вырезанных из аэрофотоснимков разливов нефти, полученных по всему миру. Для расширения обучающего набора данных применялись методы аугментации, о чем будет дополнительно сказано в разделе 6.2.

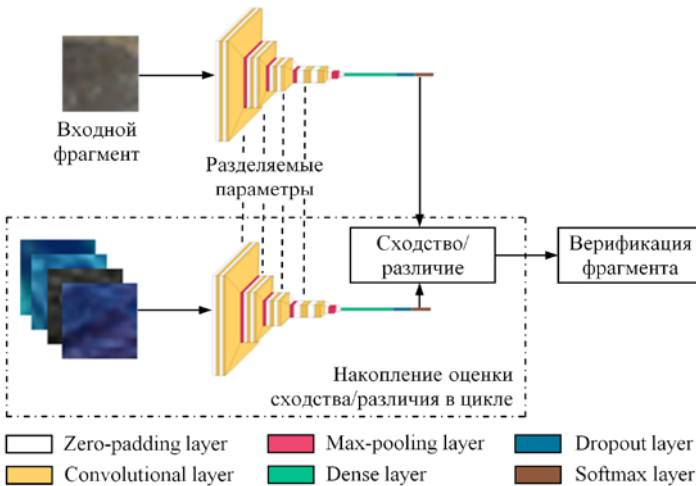


Рис. 2. Верификация фрагментов изображения на основе сиамской сети

5. Сегментация изображений разливов нефти. Помимо верификации фрагментов оптические снимки позволяют с высокой точностью оценить геометрические признаки, характеризующие форму нефтяных пятен (площадь и периметр пятен), как один из способов быстрого и эффективного мониторинга. В настоящее время общепринятыми моделями сегментации являются глубокие сети Faster R-CNN, Darknet-53, DeepLabv3+, LinkNet, SegNet и U-Net [26]. Отметим, что даже сеть U-Net, изначально спроектированная для

сегментации объектов на медицинских снимках, в настоящее время используется для сегментации разливов нефти на SAR-снимках.

Семантическая сегментация с использованием полносвязных СНС выполняется за счет того, что полносвязные выходные слои заменяются сверточными слоями с повышающей дискретизацией для предсказания выходных пикселей. Помимо этого, в сети используются соединения с пропусками (skip connections) для улучшения предсказания [27]. В свою очередь, архитектура сети U-net состоит из кодировщика и декодировщика с последовательными сверточными слоями понижающей и повышающей дискретизации соответственно [28]. При этом слои кодировщика соединены со слоями декодировщика. Такая архитектура позволяет точнее сегментировать изображения. Модель SegNet имеет аналогичную архитектуру кодировщика-декодировщика, но использует билинейную интерполяцию на уровне декодировщика, что позволяет уменьшить количество обучаемых параметров и тем самым ускорить обучение [29]. Основу кодировщика сети SegNet составляют сверточные слои сети VGG16. Декодировщик состоит из транспонированных сверточных слоев и слоев повышающей дискретизации, а его структура симметрична структуре кодировщика. Недавние исследования привели к созданию гибридной модели U-SegNet, использующей мультимасштабные признаки и сверточные слои, основанные на внимании [30].

В работе [31] была предложена модификация одноэтапного многофункционального детектора YOLO, названная как Poly-YOLOv3, которая способна выполнять сегментацию визуальных объектов. Однако следует отметить, что сегментация, выполняемая сетью Poly-YOLOv3, основана на переводе изображения объекта из декартовой системы в полярную систему координат с началом в центральной точке обрамляющего прямоугольника. Иными словами, сеть Poly-YOLOv3 предназначена для сегментации объектов выпуклых форм. В редких случаях при сильных вихревых течениях форма нефтяного пятна перестает быть выпуклой, что приводит к неточным результатам сегментации. Неоспоримым преимуществом сетей семейства YOLO является их высокое быстродействие.

Для сегментации изображений верифицированных нефтяных пятен использовались три архитектуры глубоких сетей, а именно U-Net, SegNet и Poly-YOLOv3. На рисунке 3 приведены примеры бинарных масок, построенных различными методами.




Рис. 3. Примеры сегментации изображений нефтяных пятен: а) исходные снимки, б) бинарные маски, построенные экспертом, в) бинарные маски, полученные сетью U-Net, г) бинарные маски, полученные сетью SegNet, д) бинарные маски, полученные сетью Poly-YOLOv3

Как видно из рисунка 3, бинарные маски, построенные сетями U-Net и SegNet, почти идентичны. Сеть Poly-YOLOv3 дает визуально лучшие результаты сегментации участков разливов нефти. Обобщенные оценки точности сегментации трем сетями приведены в разделе 6.4.

6. Экспериментальные исследования. В данном разделе представлено описание набора данных, собранного из нескольких открытых источников. Для увеличения собранного набора данных и

устранения несбалансированности классов применены методы аугментации. Приведены оценочные метрики, а также экспериментальные настройки и полученные результаты.

6.1. Набор данных. В отличие от доступных наборов космических SAR снимков с разливами нефти, аэрофотоснимки оптических и/или мультиспектральных изображений отсутствуют в открытом доступе. Был собран собственный набор данных из открытых источников, в частности, с сайтов Alamy [32], Getty Images [33] и др.

Собранный набор данных содержит 380 изображений морской поверхности с разливами нефти, 135 изображений «чистой» морской поверхности и 35 изображений «двойников», большинство из которых получено при съемке с беспилотных летательных аппаратов и средств малой авиации по всему миру. Съемка осуществлялась при различных высотах полета и погодных условиях, в результате чего снимки можно классифицировать по следующим показателям:

- виду местности (прибрежные районы, пляж, морские акватории);
- наличие дополнительных объектов (корабли, дым, лес, горы, люди);
- погодным условиям (облачно/солнечно);
- условиям освещенности (дневные/вечерние);
- цветам разливов нефти (красный, оранжевый, желтый, зеленый).

Разрешение изображений варьируется от нескольких сотен до тысяч пикселей. На рисунке 4 приведены примеры изображений собранного набора данных.

Изображения с разрешением 1250×650 были разбиты на фрагменты размером 128×128 путем кадрирования и сканирования изображений с использованием ядра размерностью 128×128 и шагом 1. Далее сгенерированные патчи проверялись на наличие участков с разливом нефти и участков «чистой» морской поверхности и «двойников», тем самым выполнялась ручная разметка фрагментов. В общей сложности было отобрано 199990 фрагментов, из которых около 70% относится к разливам нефти, а остальные – к «чистой» морской поверхности и «двойникам». В силу того, что изображений «двойников» слишком мало для решения задачи верификации, потребовалось выполнить аугментацию не только простыми методами, но и с использованием генеративных состязательных сетей.




Рис. 4. Примеры изображений собранного набора данных

6.2. Аугментация. Аугментация как процесс контролируемого увеличения примеров для обучения глубоких сетей является широко распространенной практикой для частных задач, для которых отсутствуют свободно распространяемые наборы данных, количество примеров невелико или набор данных является несбалансированным. Задача верификации разливов нефти относится именно к таким частным задачам в силу ряда объективных обстоятельств экологического и материального характера.

Известны разные подходы к классификации методов аугментации. Наиболее полный обзор с целью выбора приемлемых методов аугментации для конкретного приложения можно найти в работе [34]. Методы аугментации изображений разделяются на три основных категории: методы, основанные на преобразованиях (их иногда называют простыми методами аугментации), модельные методы, создающие изображения с помощью обученной модели, и оптимальные методы на основе политик, предполагающие нахождение оптимальных стратегий аугментации.

В данной работе были использованы методы из первых двух категорий, предназначенные для обработки одиночных снимков (технологии перемешивания изображений не использовались):

- методы первой категории, основанные на простых преобразованиях, таких как геометрические преобразования, преобразования цветового пространства, ядерные фильтры и случайная обрезка;

– методы второй категории, основанные на состязательном обучении, а именно метод аугментации с использованием генеративно-состязательных сетей. Такие методы характеризуются тем, что теоретически распределение сгенерированных изображений аналогично распределению исходного набора данных, однако сгенерированные изображения не совпадают с исходными изображениями.

Приведем параметры аугментации методов, основанных на преобразованиях, которые были использованы для расширения набора данных и компенсации несбалансированности двух классов:

- сдвиги по осям OX и OY не более 10% от разрешения исходного снимка;
- повороты в диапазоне $[-45^\circ \dots 45^\circ]$;
- отражение по горизонтали или вертикали;
- растяжение/сжатие в диапазоне $[0,75 \dots 1,25]$;
- масштабирование до 25%;
- равномерное наложение белого шума со случайным изменением яркости в цветовом канале в диапазоне $[-30 \dots 30]$;
- изменение яркости в каждом цветовом канале не более 15%;
- размытие с помощью гауссова фильтра;
- изменение резкости с помощью фильтра краев.

Следует отметить, что исходные изображения имели разрешение, достаточное для того, чтобы разрешение аугментированных изображений соответствовало заранее установленному разрешению входных изображений, подаваемых на сиамскую сеть.

Дополнительно, был применен метод аугментации с использованием сети GAN. Изначально архитектура GAN основывалась на том, что генератор и дискриминатор представляют многослойные перцептроны. Однако в настоящее время считается более перспективным способом аугментации применение таких GAN сетей, как DCGANs, Progressively Growing GANs, CycleGANs и Conditional GANs. В данной работе была применена глубокая сверточная сеть GAN (Deep Convolutional GANs, DCGAN) [35].

В результате аугментации количество фрагментов «двойников» возросло до 4600. Далее весь сформированный набор данных был разделен на обучающую и тестовую выборки в соотношении 70:30.

6.3. Оценочные метрики. Оценка точности сегментации нефтяных пятен проводилась с использованием пяти показателей, вычисляемых по матрице неточностей [36], а именно:

- верность AC , показывает отношение правильного прогноза к общему наблюдению;
- точность PR , указывает на соотношение правильно сегментированных пикселей;
- полнота RE , показывает, какую долю пикселей положительного класса из всех пикселей положительного класса нашел алгоритм;
- мера F_1 , характеризует степень совпадения предсказанной границы с истинной границей классов;
- пересечение по объединению IoU , также называемое коэффициентом перекрытия Жаккара (Jaccard), указывает на отношение сходства между предсказанным регионом и истинным регионом класса.

6.4. Экспериментальные настройки и полученные результаты. В экспериментах была использована облегченная сеть VGG-16, являющаяся базовой для сямской сети [24]. Данная модель концептуально повторяет архитектуру полной модели СНС, однако она учитывает особенности в связи с обработкой снимков ДЗЗ низкого разрешения, которые имеют относительно малое количество точечных особенностей. Архитектура облегченной сети VGG-16, адаптированная под обработку фрагментов изображений, представлена в таблице 1.

Слой Zero-padding (слой нулевого заполнения) повышает нелинейность сети, более точно извлекая характерные особенности снимков ДЗЗ. Размер фильтров в слое Convolutional составляет 3×3 . Слой Max-pooling (слой подвыборки) нелинейно уплотняет карту признаков. Слой Dense – это плотно связанный слой. Слой Dropout обеспечивает регуляризацию с целью уменьшения переобучения сети. Слой Softmax применяет обобщенную логистическую функцию к выходу сети.

Для разработки архитектуры сети была использована открытая библиотека Keras, написанная на языке Python. Обучение облегченной сети VGG-16 проводилось со следующими параметрами: размер пакета – 32, значение импульса – 0,9, скорость обучения – 0,001, алгоритм оптимизации – Adam, количество эпох обучения – 100. Среднее время обучения составило 30 часов. На рисунках 5 и 6 приведены графики функций точности и функций потерь в процессе обучения (training) и тестирования (testing) сети VGG-16.

Таблица 1. Архитектура облегченной сети VGG-16

Слой		Входная размерность	Выходная размерность
Input image		128×128×3	
Zero-padding		128×128×3	128×128×64
Convolutional 64+ReLU	3-	128×128×3	128×128×64
Zero-padding		128×128×3	128×128×64
Convolutional 64+ReLU	3-	128×128×3	128×128×64
Max-pooling		2×2	
Zero-padding		128×128×64	64×64×128
Convolutional 128+ReLU	3-	128×128×64	64×64×128
Zero-padding		128×128×64	64×64×128
Convolutional 128+ReLU	3-	128×128×64	64×64×128
Max-pooling		2×2	
Zero-padding		64×64×128	32×32×256
Convolutional 256+ReLU	3-	64×64×128	32×32×256
Zero-padding		64×64×128	32×32×256
Convolutional 256+ReLU	3-	64×64×128	32×32×256
Max-pooling		2×2	
Zero-padding		16×16×512	16×16×512
Convolutional 512+ReLU	3-	16×16×512	16×16×512
Zero-padding		16×16×512	16×16×512
Convolutional 512+ReLU	3-	16×16×512	16×16×512
Max-pooling		2×2	
Dense		16×16×512	1×1×4096
Dropout		1×1×0,5	
Softmax		1×1×1000	1×1×1000




Рис. 5. Графики функций точности при обучении и тестировании сети VGG-16

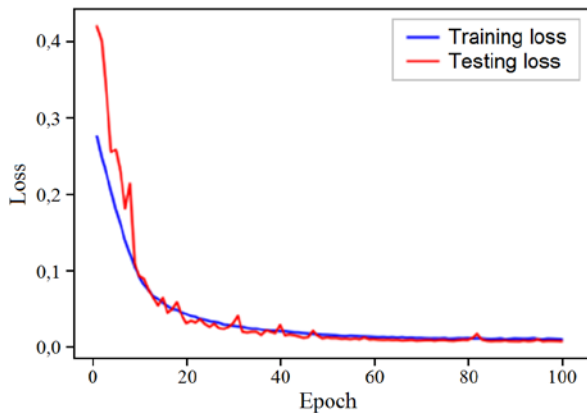


Рис. 6. Графики функций потерь при обучении и тестировании сети VGG-16

В таблице 2 приведены результаты классификации тестовых RGB изображений, относящихся к двум классам – разлив нефти и «двойники», предложенной сиамской нейронной сетью.

Таблица 2. Результаты классификации тестовых RGB изображений

Класс	AC	PR	RE	F_1	IoU
Разлив нефти	0,910	0,920	0,938	0,930	0,870
«Двойники»	0,834	0,864	0,855	0,867	0,751

После верификации областей разлива нефти требуется выполнить их сегментацию. Причем, как правило, рядом с основным нефтяным пятном имеются небольшие нефтяные пятна, что можно считать дополнительным признаком наличия разлива нефти. Для семантической сегментации были протестированы три сети U-Net, SegNet и Poly-YOLOv3 с небольшими модификациями слоев. Результаты семантической сегментации тестовых RGB изображений приведены в таблице 3.

Таблица 3. Результаты сегментации тестовых RGB изображений

Сеть	<i>AC</i>	<i>PR</i>	<i>RE</i>	F_1	Среднее время, с
U-Net	0,802	0,8695	0,8450	0,8571	458
SegNet	0,827	0,8529	0,8787	0,8656	625
Poly-YOLOv3	0,924	0,9705	0,9166	0,9428	385

Как видно из таблицы 3, лучшие результаты по точности сегментации и быстродействию показала сеть Poly-YOLOv3, позволяющая не только обнаруживать и распознавать объекты, но и определять их форму. Кроме того, сеть Poly-Yolov3 относится к одноэтапным детекторам, что приводит к сокращению времени вычислений. Тестирование проводилось с помощью веб-сервиса Google Colab.

Дополнительно была разработана база данных под управлением свободно распространяемой СУБД MySQL 5.7, которая хранит информацию об исходных снимках и результатах верификации и сегментации в виде визуальных и числовых данных. В описание исходных снимков входят следующие атрибуты:

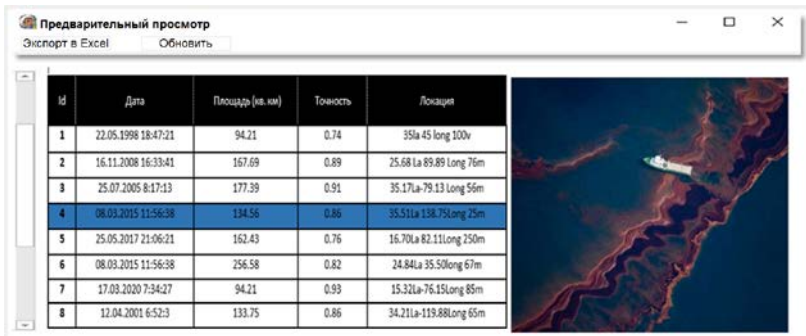
- идентификатор снимка;
- наименование снимка;
- географические координаты;
- тип и вид прибора (при наличии);
- разрешение снимка;
- дата съемки;
- дата обработки;
- идентификатор пользователя.

В описание обработанных снимков входят следующие атрибуты:

- идентификатор снимка;
- результат верификации (1/0);
- площадь основного нефтяного пятна;

- количество дополнительных нефтяных пятен;
- средняя площадь дополнительных нефтяных пятен;
- дата обработки;
- идентификатор пользователя.

На рисунке 7 приведен пример экранной формы предварительного просмотра аэрофотоснимков.



id	Дата	Площадь (кв. км)	Точность	Локация
1	22.05.1998 18:47:21	94.21	0.74	351a 45 long 100v
2	16.11.2008 16:33:41	167.69	0.89	25.68 1a 89.89 Long 76m
3	25.07.2005 8:17:13	177.39	0.91	35.171a-79.13 Long 56m
4	08.03.2015 11:56:38	134.56	0.86	35.511a 138.75long 25m
5	25.05.2017 21:06:21	162.43	0.76	16.701a 82.111long 250m
6	08.03.2015 11:56:38	256.58	0.82	24.841a 35.50long 67m
7	17.03.2020 7:34:27	94.21	0.93	15.321a-76.151Long 85m
8	12.04.2001 6:52:3	133.75	0.86	34.211a-119.88Long 65m

Рис. 7. Пример экранной формы «Предварительный просмотр»

Также имеются транзакционные таблицы, позволяющие хранить и обрабатывать несколько снимков одной и той же территории, но полученных в разное время с целью мониторинга разлива нефти. База данных содержит 14 связанных таблиц, 2 представления. Также реализованы 3 отчета и экспорт данных о снимках в Excel.

7. Заключение. В статье рассматривается задача верификации разливов нефти по оптическим аэрофотоснимкам как задача бинарной классификации. Впервые предложено решение на основе сиамской сети, когда поступающий фрагмент сравнивается с репрезентативными фрагментами нефтяных пятен в пространстве признаков. Для обучения сиамской сети используется контрастная функция потерь. Основой сиамской сети служит облегченная сеть VGG-16. Решение о верификации снимка принимается, если количество фрагментов, классифицированных как разлив нефти, превысило установленное значение. Далее выполняется сегментация нефтяных пятен, основного и дополнительных, которые, как правило, возникают при разливах нефти. Для этого используются сети семантической сегментации. Проведено экспериментальное исследование трех сетей, а именно U-Net, SegNet и Poly-YOLOv3. Наилучшую точность и наилучшее быстроедействие на собранном наборе данных показала сеть Poly-YOLOv3. Дополнительно разработано приложение для построения

бинарных масок и вычисления относительной площади разлива нефти. Как исходные снимки с соответствующими атрибутами, так и результаты сегментации записываются в разработанную базу данных, работающую под управлением СУБД MySQL 5.7 с использованием dbForge Studio 2020 for MySQL. Такое решение является удобным для конечного пользователя, который формирует запросы и отчеты для мониторинга экологической ситуации.

Литература

1. Ivshina I.B., Kuyukina M.S., Krivoruchko A.V., Elkin A.A., Makarov S.O., Cunningham C.J., Peshkur T.A., Atlas R.M., Philp J.C. Oil spill problems and sustainable response strategies through new technologies // *Environmental Science: Processes & Impacts journal*. 2015. vol. 17. no. 7. pp. 1201-1219.
2. Hackett B., Comerma E., Daniel P., Ichikawa H. Marine oil pollution prediction // *Oceanography*. 2009. vol. 22. pp. 168-175.
3. Wang R.; Zhu Z.; Zhu W.; Fu X., Xing S. A dynamic marine oil spill prediction model based on deep learning // *Journal of Coastal Research*. 2021. vol. 37. no. 4. pp. 716-725.
4. Lubchenco J., McNutt M.K., Dreyfus G., Murawski S.A., Kennedy D.M., Anastas P.T., Chu S., Hunter T. Science in support of the deepwater horizon response // *PNAS*. 2012. vol. 109. no. 50. pp. 20212-20221.
5. Mera D., Bolon-Canedo V., Cotos J.M., Alonso-Betanzos A. On the use of feature selection to improve the detection of sea oil spills in SAR images // *Computers & Geosciences*. 2017. vol. 100. pp. 166-178.
6. Zeng K., Wang Y. A deep convolutional neural network for oil spill detection from spaceborne SAR images // *Remote Sensing*. 2020. vol. 12. no. 6. pp. 1015.1-1015.23.
7. Chen G., Li Y., Sun G., Zhang Y. Application of deep networks to oil spill detection using polarimetric synthetic aperture radar images // *Applied Sciences*. 2017. vol. 7. no. 10. pp. 968.1-968.15.
8. Bianchi F.M., Espeseth M.M., Borch N. Large-scale detection and categorization of oil spills from SAR images with deep learning // *Remote Sensing*. 2020. vol. 12. pp. 2260.1-2260.27.
9. Angelliaume S., Ceamanos X., Viallefont-Robinet F., Baque R., Deliot P., Miegbielle V. Hyperspectral and radar airborne imagery over controlled release of oil at sea // *Sensors*. 2017. vol. 17. no. 8. pp. 1772.1-1772.21.
10. Huang H., Wang C., Liu S., Sun Z., Zhang D., Liu C., Jiang Y., Zhan S., Zhang H., Xu R. Single spectral imagery and Faster R-CNN to identify hazardous and noxious substances spills // *Environmental Pollution*. 2020. vol. 258. pp. 113688.1-113688.11.
11. Wang D., Wan J., Liu S., Chen Y., Yasir M., Xu M., Ren P. BO-DRNet: An improved deep learning model for oil spill detection by polarimetric features from SAR images // *Remote Sensing*. 2022. vol. 14. pp. 264.1-264.18.
12. Aghaei N., Akbarizadeh G., Kosarian A. GreyWolfLSM: An accurate oil spill detection method based on level set method from synthetic aperture radar imagery // *European Journal of Remote Sensing*. 2022. vol. 55. no. 1. pp. 181-198.
13. Chen Y., Sun Y., Yu W., Liu Y, Hu H. A novel lightweight bilateral segmentation network for detecting oil spills on the sea surface // *Marine Pollution Bulletin*. 2022. vol. 175. pp. 113343.1-113343.12.
14. Paoletti M.E., Haut J.M., Pereira N.S. Ghostnet for hyperspectral image classification // *IEEE Transactions on Geoscience and Remote Sensing*. 2021. vol. 59. no. 12. pp. 10378-10393.

15. Bulgarelli B., Djavidnia S. On MODIS Retrieval of oil spill spectral properties in the marine environment // *IEEE Geoscience and Remote Sensing Letters*. 2012. vol. 9. no. 3. pp. 398-402.
16. Lu Y., Shi J., Wen Y., Hu C., Zhou Y., Sun S., Zhang M., Mao Z., Liu Y. Optical interpretation of oil emulsions in the ocean – Part I: Laboratory measurements and proof-of-concept with AVIRIS observations // *Remote Sensing of Environment*. 2019. vol. 230. pp. 111183.1-111183.14.
17. Lu Y., Shi J., Hu C., Zhang M., Sun S., Liu Y. Optical interpretation of oil emulsions in the ocean – Part II: Applications to multi-band coarse-resolution imagery // *Remote Sensing of Environment*. 2020. vol. 242. pp. 111778.1-111778.14.
18. Yang Z., Chen Z., Lee K., Owens E., Boufadel M.C., C., Taylor E. Decision support tools for oil spill response (OSR-DSTs): Approaches, challenges, and future research perspectives // *Marine Pollution Bulletin*. 2021. vol. 167. pp. 112313.1-112313.16.
19. Mohammadiun S., Hu G., Gharahbagh A.A., Jianbing Li c, Hewage K., Sadiq R. Evaluation of machine learning techniques to select marine oil spill response methods under small-sized dataset conditions // *Journal of Hazardous Materials*. 2022. vol. 436. pp. 129282.1-129282.11.
20. Guo Y., Zhang H.Z. Oil spill detection using synthetic aperture radar images and feature selection in shape space // *International Journal of Applied Earth Observation and Geoinformation*. 2014. vol. 30, pp. 146-157.
21. Bromley J., Bentz J.W., Bottou L., Guyon I., Lecun Y., Moore C., Säckinger E., Shah R. Signature verification using a "siamese" time delay neural network // *International Journal of Pattern Recognition and Artificial Intelligence*. 1993. vol. 7. no. 4. pp. 669-688.
22. Yelchuri R., Dash J.K., Singh P., Mahapatro A., Sibarama S. Exploiting deep and hand-crafted features for texture image retrieval using class membership // *Pattern Recognition Letters*. 2022. vol. 160. pp. 163-171.
23. Chen L.C., Papandreou G., Kokkinos I., Murphy K., Yuille A.L. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs // *IEEE Transactions on Pattern Analysis & Machine Intelligence*. 2018. vol. 40. no. 4. pp. 834-848.
24. Ye M., Ruiwen N., Chang Z., He G., Tianli H., Shijun L., Yu S., Tong Z., Ying G. A lightweight model of VGG-16 for remote sensing image classification // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021. vol. 14. pp. 6916-6922.
25. Caron M., Misra I., Mairal J., Goyal P., Bojanowski P., Joulin A. Unsupervised learning of visual features by contrasting cluster assignments // *Proceeding of the 34th International Conference on Neural Information Processing Systems (NIPS'20)*. 2020. Article no. 831. pp. 9912-9924.
26. de Moura N.V.A., de Carvalho O.L.F., Gomes R.A.T., Guimaraes R.F., de Carvalho Júnior O.A. Deep-water oil-spill monitoring and recurrence analysis in the brazilian territory using Sentinel-1 time series and deep learning // *International Journal of Applied Earth Observations and Geoinformation*. 2022. vol. 107. pp. 102695.1-102695.11.
27. Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2015. pp. 3431-3440.
28. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation // *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*. 2015. pp. 234-241.

29. Badrinarayanan V.; Kendall A.; Cipolla R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2017. vol. 39. pp. 2481-2495.
30. Dayananda C., Choi J.-Y., Lee B. Multi-scale squeeze U-SegNet with multi global attention for brain MRI segmentation // Sensors. 2021. vol. 21. pp. 3363.1-3363.22.
31. Hurtik P., Molek V., Hula J., Vajgl M., Vlasanek P., Nejezchleba T. Poly-YOLO: Higher speed, more precise detection and instance segmentation for YOLOv3 // CoRR arXiv preprint, arXiv:2005.13243v2. 2020. pp. 1-18.
32. Alamy [Official web site Alamy Stock photography]. Available at: www.alamy.com. (accessed 26.07.2022).
33. Getty Images [Official web site of Getty Images]. Available at: www.gettyimages.nl. (accessed 26.07.2022).
34. Xu M., Yoon S., Fuentes A., Park D.S. A comprehensive survey of image augmentation techniques for deep learning // CoRR arXiv preprint, arXiv:2205.01491v1. 2022. pp. 1-41.
35. Radford A., Metz L., Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks // The 4th International Conference on Learning Representations (ICLR 2016). 2016. pp. 1-16.
36. Goodfellow I., Bengio Y., Courville A. Deep learning / Dietterich T. (ed.) // Cambridge, Massachusetts, London: The MIT Press. 2016. 800 p.

Фаворская Маргарита Николаевна — д-р техн. наук, профессор, заведующий кафедрой, кафедра информатики и вычислительной техники, Сибирский государственный университет науки и технологий имени М.Ф. Решетнева. Область научных интересов: компьютерное зрение, обработка изображений и видеопоследовательностей, глубокое обучение, распознавание образов. Число научных публикаций — 300. favorskaya@gmail.com; проспект им. газеты Красноярский рабочий, 31, 660037, Красноярск, Россия; р.т.: +7(3912)139-622.

Нишчхал Нишчхал — магистрант, кафедра информатики и вычислительной техники, Сибирский государственный университет науки и технологий имени акад. М.Ф. Решетнева. Область научных интересов: интеллектуальные системы, глубокое обучение. Число научных публикаций — 18. nik.321g@yandex.ru; проспект им. газеты "Красноярский рабочий", 31, 660037, Красноярск, Россия; р.т.: +7(3912)139-623.

M. FAVORSKAYA, N. NISHCHHAL
**VERIFICATION OF MARINE OIL SPILLS USING AERIAL
IMAGES BASED ON DEEP LEARNING METHODS**

Favorskaya M., Nishchhal N. Verification of Marine Oil Spills Using Aerial Images Based on Deep Learning Methods.

Abstract. The article solves the problem of verifying oil spills on the water surfaces of rivers, seas and oceans using optical aerial photographs, which are obtained from cameras of unmanned aerial vehicles, based on deep learning methods. The specificity of this problem is the presence of areas visually similar to oil spills on water surfaces caused by blooms of specific algae, substances that do not cause environmental damage (for example, palm oil), or glare when shooting (so-called look-alikes). Many studies in this area are based on the analysis of synthetic aperture radars (SAR) images, which do not provide accurate classification and segmentation. Follow-up verification contributes to reducing environmental and property damage, and oil spill size monitoring is used to make further response decisions. A new approach to the verification of optical images as a binary classification problem based on the Siamese network is proposed, when a fragment of the original image is repeatedly compared with representative examples from the class of marine oil slicks. The Siamese network is based on the lightweight VGG16 network. When the threshold value of the output function is exceeded, a decision is made about the presence of an oil spill. To train the networks, we collected and labeled our own dataset from open Internet resources. A significant problem is an imbalance of classes in the dataset, which required the use of augmentation methods based not only on geometric and color manipulations, but also on the application of a Generative Adversarial Network (GAN). Experiments have shown that the classification accuracy of oil spills and look-alikes on the test set reaches values of 0.91 and 0.834, respectively. Further, an additional problem of accurate semantic segmentation of an oil spill is solved using convolutional neural networks (CNN) of the encoder-decoder type. Three deep network architectures U-Net, SegNet, and Poly-YOLOv3 have been explored for segmentation. The Poly-YOLOv3 network demonstrated the best results, reaching an accuracy of 0.97 and an average image processing time of 385 s with the Google Colab web service. A database was also designed to store both original and verified images with problem areas.

Keywords: oil spill detection, verification, segmentation, deep learning, aerial photographs, Earth remote sensing.

References

1. Ivshina I.B., Kuyukina M.S., Krivoruchko A.V., Elkin A.A., Makarov S.O., Cunningham C.J., Peshkur T.A., Atlas R.M., Philp J.C. Oil spill problems and sustainable response strategies through new technologies. *Environmental Science: Processes & Impacts journal*. 2015. vol. 17. no. 7. pp. 1201-1219.
2. Hackett B., Comerma E., Daniel P., Ichikawa H. Marine oil pollution prediction. *Oceanography*. 2009. vol. 22. pp. 168-175.
3. Wang R.; Zhu Z.; Zhu W.; Fu X., Xing S. A Dynamic marine oil spill prediction model based on deep learning. *Journal of Coastal Research*. 2021. vol. 37. no. 4. pp. 716-725.
4. Lubchenco J., McNutt M.K., Dreyfus G., Murawski S.A., Kennedy D.M., Anastas P.T., Chu S., Hunter T. Science in support of the deepwater horizon response. *PNAS*. 2012. vol. 109. no. 50. pp. 20212-20221.

5. Mera D., Bolon-Canedo V., Cotos J.M., Alonso-Betanzos A. On the use of feature selection to improve the detection of sea oil spills in SAR images. *Computers & Geosciences*. 2017. vol. 100. pp. 166-178.
6. Zeng K., Wang Y. A deep convolutional neural network for oil spill detection from spaceborne SAR images. *Remote Sensing*. 2020. vol. 12. no. 6. pp. 1015.1-1015.23.
7. Chen G., Li Y., Sun G., Zhang Y. Application of deep networks to oil spill detection using polarimetric synthetic aperture radar images. *Applied Sciences*. 2017. vol. 7. no. 10. pp. 968.1-968.15.
8. Bianchi F.M., Espeseth M.M., Borch N. Large-scale detection and categorization of oil spills from SAR images with deep learning. *Remote Sensing*. 2020. vol. 12. pp. 2260.1-2260.27.
9. Angelliaume S., Ceamanos X., Viallefont-Robinet F., Baque R., Deliot P., Miegbielle V. Hyperspectral and radar airborne imagery over controlled release of oil at sea. *Sensors*. 2017. vol. 17. no. 8. pp. 1772.1-1772.21.
10. Huang H., Wang C., Liu S., Sun Z., Zhang D., Liu C., Jiang Y., Zhan S., Zhang H., Xu R. Single spectral imagery and Faster R-CNN to identify hazardous and noxious substances spills. *Environmental Pollution*. 2020. vol. 258. pp. 113688.1-113688.11.
11. Wang D., Wan J., Liu S., Chen Y., Yasir M., Xu M., Ren P. BO-DRNet: An improved deep learning model for oil spill detection by polarimetric features from SAR images. *Remote Sensing*. 2022. vol. 14. pp. 264.1-264.18.
12. Aghaei N., Akbarizadeh G., Kosarian A. GreyWolfLSM: An accurate oil spill detection method based on level set method from synthetic aperture radar imagery. *European Journal of Remote Sensing*. 2022. vol. 55. no. 1. pp. 181-198.
13. Chen Y., Sun Y., Yu W., Liu Y., Hu H. A novel lightweight bilateral segmentation network for detecting oil spills on the sea surface. *Marine Pollution Bulletin*. 2022. vol. 175. pp. 113343.1-113343.12.
14. Paoletti M.E., Haut J.M., Pereira N.S. Ghostnet for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*. 2021. vol. 59. no. 12. pp. 10378-10393.
15. Bulgarelli B., Djavidnia S. On MODIS Retrieval of oil spill spectral properties in the marine environment. *IEEE Geoscience and Remote Sensing Letters*. 2012. vol. 9. no. 3. pp. 398-402.
16. Lu Y., Shi J., Wen Y., Hu C., Zhou Y., Sun S., Zhang M., Mao Z., Liu Y. Optical interpretation of oil emulsions in the ocean – Part I: Laboratory measurements and proof-of-concept with AVIRIS observations. *Remote Sensing of Environment*. 2019. vol. 230. pp. 111183.1-111183.14.
17. Lu Y., Shi J., Hu C., Zhang M., Sun S., Liu Y. Optical interpretation of oil emulsions in the ocean – Part II: Applications to multi-band coarse-resolution imagery. *Remote Sensing of Environment*. 2020. vol. 242. pp. 111778.1-111778.14.
18. Yang Z., Chen Z., Lee K., Owens E., Boufadel M.C., C., Taylor E. Decision support tools for oil spill response (OSR-DSTs): Approaches, challenges, and future research perspectives. *Marine Pollution Bulletin*. 2021. vol. 167. pp. 112313.1-112313.16.
19. Mohammadi S., Hu G., Gharahbagh A.A., Jianbing Li C., Hewage K., Sadiq R. Evaluation of machine learning techniques to select marine oil spill response methods under small-sized dataset conditions. *Journal of Hazardous Materials*. 2022. vol. 436. pp. 129282.1-129282.11.
20. Guo Y., Zhang H.Z. Oil spill detection using synthetic aperture radar images and feature selection in shape space. *International Journal of Applied Earth Observation and Geoinformation*. 2014. vol. 30. pp. 146-157.
21. Bromley J., Bentz J.W., Bottou L., Guyon I., Lecun Y., Moore C., Säckinger E., Shah R. Signature verification using a "siamese" time delay neural network. *International*

- Journal of Pattern Recognition and Artificial Intelligence. 1993. vol. 7. no. 4. pp. 669-688.
22. Yelchuri R., Dash J.K., Singh P., Mahapatro A., Sibarama S. Exploiting deep and hand-crafted features for texture image retrieval using class membership. *Pattern Recognition Letters*. 2022. vol. 160. pp. 163-171.
 23. Chen L.C., Papandreou G., Kokkinos I., Murphy K., Yuille A.L. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Transactions on Pattern Analysis & Machine Intelligence*. 2018. vol. 40. no. 4. pp. 834-848.
 24. Ye M., Ruiwen N., Chang Z., He G., Tianli H., Shijun L., Yu S., Tong Z., Ying G. A lightweight model of VGG-16 for remote sensing image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021. vol. 14. pp. 6916-6922.
 25. Caron M., Misra I., Mairal J., Goyal P., Bojanowski P., Joulin A. Unsupervised learning of visual features by contrasting cluster assignments. *Proceedings of the 34th International Conference on Neural Information Processing Systems (NIPS'20)*. 2020. Article no. 831. pp. 9912-9924.
 26. de Moura N.V.A., de Carvalho O.L.F., Gomes R.A.T., Guimaraes R.F., de Carvalho Júnior O.A. Deep-water oil-spill monitoring and recurrence analysis in the brazilian territory using Sentinel-1 time series and deep learning. *International Journal of Applied Earth Observations and Geoinformation*. 2022. vol. 107. pp. 102695.1-102695.11.
 27. Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2015. pp. 3431-3440.
 28. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation. *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*. 2015. pp. 234-241.
 29. Badrinarayanan V.; Kendall A.; Cipolla R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017. vol. 39. pp. 2481-2495.
 30. Dayananda C., Choi J.-Y., Lee B. Multi-scale squeeze U-SegNet with multi global attention for brain MRI segmentation. *Sensors*. 2021. vol. 21. pp. 3363.1-3363.22.
 31. Hurtik P., Molek V., Hula J., Vajgl M., Vlasanek P., Nejezchleba T. Poly-YOLO: Higher speed, more precise detection and instance segmentation for YOLOv3. *CoRR arXiv preprint, arXiv:2005.13243v2*. 2020. pp. 1-18.
 32. Alamy [Official web site Alamy Stock photography]. Available at: www.alamy.com. (accessed 26.07.2022).
 33. Getty Images [Official web site of Getty Images]. Available at: www.gettyimages.nl. (accessed 26.07.2022).
 34. Xu M., Yoon S., Fuentes A., Park D.S. A comprehensive survey of image augmentation techniques for deep learning. *CoRR arXiv preprint, arXiv:2205.01491v1*. 2022. pp. 1-41.
 35. Radford A., Metz L., Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. *The 4th International Conference on Learning Representations (ICLR 2016)*. 2016. pp. 1-16.
 36. Goodfellow I., Bengio Y., Courville A. *Deep learning*. Dietterich T. (ed.). The MIT Press. 2016. 800 p.

Favorskaya Margarita — Ph.D., Dr.Sci., Professor, Head of the department, Department of informatics and computer techniques, Reshetnev Siberian State University of Science and Technology. Research interests: computer vision, image and video sequence processing, deep

learning, pattern recognition. The number of publications — 300. favorskaya@gmail.com; 31, Krasnoyarsky Rabochy Av., 660037, Krasnoyarsk, Russia; office phone: +7(3912)139-622.

Nishchhal Nishchhal — Master student, Department of informatics and computer techniques, Reshetnev Siberian State University of Science and Technology. Research interests: intelligent systems, deep learning. The number of publications — 18. nik.321g@yandex.ru; 31, Krasnoyarsky Rabochy Av., 660037, Krasnoyarsk, Russia; office phone: +7(3912)139-623.